

**ÓPTIMA UBICACIÓN DE GENERACIÓN DISTRIBUIDA EN REDES DE
DISTRIBUCIÓN CON EL USO DE REDES NEURONALES ARTIFICIALES.**

UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE QUITO

CARRERA:
INGENIERÍA ELÉCTRICA

Trabajo de titulación previo a la obtención del título de
INGENIERO ELÉCTRICO

TEMA:
ÓPTIMA UBICACIÓN DE GENERACIÓN DISTRIBUIDA EN REDES DE
DISTRIBUCIÓN CON EL USO DE REDES NEURONALES ARTIFICIALES.

AUTOR:
FLORES FLORES MARLON STEVEN

TUTOR:
JARAMILLO MONGE MANUEL DARIO

QUITO, Agosto 2021

Flores Flores Marlon Steven

**ÓPTIMA UBICACIÓN DE GENERACIÓN DISTRIBUIDA EN REDES DE DISTRIBUCIÓN
CON EL USO DE REDES NEURONALES ARTIFICIALES.**

Universidad Politécnica Salesiana
Ingeniería Eléctrica

Breve reseña histórica e información de contacto.



Flores Flores Marlon Steven (Y'1996). Realizó sus estudios secundarios en el Colegio C.E.I.A.F (Antonio Flores), se graduó de bachiller Físico Matemático. Egresado de la carrera de Ingeniería Eléctrica de la Universidad Politécnica Salesiana.
mfloresf1@est.ups.edu.ec

Dirigido por:



Jaramillo Monge Manuel Dario (Y'1990). Realizó sus estudios superiores en la Universidad de las Fuerzas Armadas ESPE de Quito, donde se graduó de Ingeniero Electrónico en Automatización y Control en el 2014. Además, cursó estudios de posgrado en la Universidad de Newcastle, Reino Unido, donde obtuvo el título en Máster en Electrical Power. Actualmente es profesor ocasional a tiempo completo de la Universidad Politécnica Salesiana.
mjaramillo@ups.edu.ec

Todos los derechos reservados:

Queda prohibida, salvo excepción prevista en la ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con la autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos o investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS
©2021 Universidad Politécnica Salesiana
QUITO - ECUADOR

DECLARATORIA DE COAUTORÍA DEL DOCENTE TUTOR

Yo, Jaramillo Monge Manuel Dario declaro que bajo mi dirección y asesoría fue desarrollado el trabajo de titulación *ÓPTIMA UBICACIÓN DE GENERACIÓN DISTRIBUIDA EN REDES DE DISTRIBUCIÓN CON EL USO DE REDES NEURONALES ARTIFICIALES*, realizado por Marlon Steven Flores Flores, obteniendo un producto que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana para ser considerado como trabajo final de titulación.

Quito D.M., Agosto de 2021



.....
Jaramillo Monge Manuel Dario

C.C.: 1714298005

CESIÓN DE DERECHOS DE AUTOR

Yo, Flores Flores Marlon Steven, con documento de identificación N° 1751629963, manifiesto mi voluntad y cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del trabajo de grado/titulación intitulado: *ÓPTIMA UBICACIÓN DE GENERACIÓN DISTRIBUIDA EN REDES DE DISTRIBUCIÓN CON EL USO DE REDES NEURONALES ARTIFICIALES*, mismo que ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia, suscribo este documento en el momento que hago entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.



.....
Flores Flores Marlon Steven

C.C.: 1751629963

Quito, D.M., Agosto de 2021

ÍNDICE GENERAL

Resumen	1
Abstract	1
1 Introducción.....	2
2 Marco Teórico.....	3
2.1 Compensación de Potencia Activa y Reactiva.....	3
2.2 Tipos de Compensación.....	4
2.2.1 Compensación reactiva paralelo pura	4
2.2.2 Compensación reactiva en serie	4
2.2.3 Maquinas Sincrónicas	4
2.2.4 SVC.....	4
2.3 Métodos Para Encontrar la Óptima Ubicación de Compensación	5
2.3.1 Algoritmo de búsqueda exhaustiva	5
2.3.2 Algoritmo K-NN (K Nearest Neighbourst).....	5
2.3.3 Función Multiobjetivo.....	5
2.3.4 Redes Neuronales.....	5
2.4 Redes Neuronales.....	5
2.5 Topologías de Redes Neuronales.....	6
2.6 Tipos de redes neuronales.....	6
2.6.1 Redes con aprendizaje supervisado.....	6
2.6.2 Redes con aprendizaje no supervisado.....	7
2.6.3 Redes neuronales de predicción	8
3 Planteamiento del Problema	8
3.1 Sistemas de Prueba	8
3.1.1 Sistema IEEE de 34 Barras	8
3.1.2 Sistema IEEE de 33 Barras	8
3.2 Generación Distribuida.....	9
3.3 Óptima Ubicación Mediante Redes Neuronales	10
3.3.1 Descripción del algoritmo con una sola unidad de generación	10
3.3.2 Descripción del algoritmo con dos unidades de generación	10
4 Casos de estudio	11
4.1 Escenario con una sola generación.....	11
4.1.1 Caso 1	11
4.1.2 Caso 2	11
4.2 Escenario con dos generaciones	12

4.2.1	Caso 3	12
4.2.2	Caso 4	12
5	Análisis de resultados	12
5.1	Caso 1.	12
5.2	Caso 2	14
5.3	Caso 3.	15
5.4	Caso 4.	16
6	Conclusiones	18
7	Referencias	18
8.	Estado del arte	21
8.1	Resumen de indicadores	23

ÍNDICE DE FIGURAS

Figura 1. Redes neuronales	5
Figura 2. Red neuronal monomodo.....	6
Figura 3. Red neuronal multimodo.....	6
Figura 4. Red neuronal aprendizaje supervisado.....	6
Figura 5. Red neuronal con aprendizaje supervisado	7
Figura 6. Red neuronal de predicción.	8
Figura 7. Sistema de prueba de 34 barras.....	8
Figura 8. Sistema de prueba de 33 barras.....	9
Figura 9. Sistema de prueba 33 barras a 200kV	13
Figura 10. Estado del entrenamiento de 33 barras a 200kV.	13
Figura 11. Matriz de entrenamiento de 33 barras a 200 kV	13
Figura 12. Clasificación realizada por RNA de 33 barras a 200 kV.....	14
Figura 13. Sistema de prueba 33 barras a 300kV	14
Figura 14. Estado de entrenamiento de 33 barras a 300kV	14
Figura 15. Matriz de entrenamiento de 33 barras a 300kV	14
Figura 16. Clasificación realizada por RNA de 33 barras a 300 kV.....	15
Figura 17. Sistema de prueba 33 barras a 200kV combinado	15
Figura 18. Estado de entrenamiento de 33 barras a 200kV combinado	15
Figura 19. Matriz de entrenamiento de 33 barras a 200kV combinado.....	16
Figura 20. Clasificación realizada por RNA de 33 barras a 200kV combinado.....	16
Figura 21. Sistema de prueba 33 barras a 300kV combinado	17
Figura 22. Estado de entrenamiento de 33 barras a 300kV combinado	17
Figura 23. Matriz de entrenamiento de 33 barras a 300kV combinado.....	17
Figura 24. Clasificación realizada por RNA de 33 barras a 300kV combinado.....	18
Figura 25. Resumen e indicador de la temática - Estado del arte.....	23
Figura 26. Indicador de la formulación del problema - Estado del arte.....	23
Figura 1. Indicador de solución - Estado del arte.....	24

ÍNDICE DE TABLAS

Tabla 1. Datos de potencia de unidades de generación	9
Tabla 2. Óptima ubicación de UDG en sistemas de distribución mediante RNA en MATLAB.	10
Tabla 3. Parámetros de la red neuronal en MATLAB.....	10
Tabla 4. Obtención de datos del sistema de distribución IEEE de 33 barras.....	11
Tabla 5. Parámetros de la óptima ubicación Caso 1	11
Tabla 6. Parámetros de la óptima ubicación Caso 2.....	12
Tabla 7. Parámetros de la óptima ubicación Caso 3.....	12
Tabla 8. Parámetros de la óptima ubicación Caso 4.....	12
Tabla 9. Comprobaciones de los subcasos de un sistema IEEE de 34 barras	13
Tabla 10. Comprobaciones de los subcasos de un sistema IEEE de 34 barras	15
Tabla 11. Comprobaciones de los subcasos de un sistema IEEE de 34 barras	16
Tabla 12. Comprobaciones de los subcasos de un sistema IEEE de 34 barras	17
Tabla 13. Matriz de estado del arte.....	23

ÓPTIMA UBICACIÓN DE GENERACIÓN DISTRIBUIDA EN REDES DE DISTRIBUCIÓN CON EL USO DE REDES NEURONALES ARTIFICIALES.

Resumen

En el presente trabajo se desarrolla el entrenamiento de redes neuronales artificiales por medio del software MATLAB simulink, con la finalidad de encontrar la óptima ubicación de unidades de generación distribuida (potencia reactiva) en el sistema de distribución IEEE de 34 barras. Para la creación y entrenamiento de las redes neuronales artificiales se utilizará el sistema de prueba del IEEE de 33 barras.

Posteriormente, a este sistema se le añade o añaden una o dos unidades de generación con valores especificados en el planteamiento del problema; se tendrán las variables de interés (voltajes en las barras) las cuales se utilizarán como datos para el entrenamiento de la red.

Una vez realizado el entrenamiento de la RNA se procede a valorar en el sistema de distribución IEEE de 34 barras, permitiendo identificar cuál es la ubicación óptima de UGD para la mejora de perfiles de voltaje.

Finalmente se presentan algunos resultados de los casos de estudio propuestos, como el tiempo que tarda en entrenarse la RNA, la mejor validación, la efectividad del entrenamiento de la red entre otros parámetros.

Palabras clave: Redes neuronales, potencia reactiva, voltaje, ubicación, óptimo.

Abstract

In the present work, artificial neural network training is developed by means of the MATLAB simulink software, in order to find the optimal location of distributed reactive power generation units in the IEEE 34-bus distribution system. For the creation and training of artificial neural networks, the IEEE 33-bar test system will be used.

Subsequently, to this system one or two generation units are added or added with values specified in the problem statement; we will have the variables of interest (voltages in the bars) which will be used as data for the training of the network.

Once the ANN training has been carried out, the IEEE 34-bar distribution system is evaluated, allowing the identification of the optimal location of the UGD for the improvement of voltage profiles.

Finally, some results of the proposed case studies are presented, such as the time it takes to train the ANN, the best validation, the effectiveness of the network training, among other parameters.

Keywords: Neural networks, reactive power, voltage, location, optimal.

1 Introducción.

En el siguiente artículo se va a realizar una investigación acerca de la óptima ubicación de compensadores de potencia utilizando redes neuronales en sistemas de distribución, tomando como prueba el sistema de 33 y 34 nodos de la IEEE para encontrar el mejor lugar en donde se pueden ubicar.

Se definen conceptos claves como la compensación activa y reactiva que se realizan en los sistemas, tratando de compensar valores de potencia y a su vez tratando de dar una estabilidad al sistema en parámetros como frecuencia y voltaje [1], [31].

Además, se detallan los tipos de compensación y con el siguiente análisis evaluar en qué lugar es lo más óptimo colocar compensadores de potencia y el tipo de compensadores que se deben colocar utilizando un flujo de redes neuronales. [2].

Se detallan y se analizan métodos para encontrar la óptima ubicación de compensación de reactivos en los cuales estará incluido el análisis de redes neuronales en donde se requiere encontrar que a través de las redes neuronales es más factible encontrar el lugar más adecuado para la implementación de redes neuronales, tomando en cuenta el tipo de red neuronal en los casos de estudios variando el voltaje y la potencia de cada sistema.

Al detallar una red neuronal se halla que la red neuronal se la define por tres factores importantes, los cuales son la arquitectura de red, función de transferencia y ley de aprendizaje. Estos factores están definidos siempre en función del problema.

Algo que destacar para la comprensión de las redes neuronales son los tres elementos básicos de una red neuronal los cuales son la capa de entrada, ocultas y la de salida, en donde la función que realiza la capa de entrada es de recibir información desde el exterior, la función de las capas ocultas es la comunicación entre la capa de entrada y de salida, la función de la capa de salida es brindar los resultados al exterior [21].

Además, existen dos topologías principales en las redes neuronales las cuales son mono capa y multicapa, en donde las redes mono capa realizan conexiones pertenecientes a la misma capa o en palabras más simples realizan una auto conexión, en cambio las redes multicapa tienen un conjunto agrupado de neuronas en distintas capas y para distinguir el nivel al que pertenece la neurona, se realiza un análisis de las señales que llegan a la capa de entrada.

Todos estos parámetros de una red neuronal van a ayudar a encontrar la óptima ubicación para la implementación de compensadores reactivos, ya sea agrupando entre datos de la misma capa o haciendo agrupaciones de distintas capas y realizando otra agrupación entre los datos que tengan una similitud o una igualdad [22].

Motivo por el cual se realiza una subagrupación es debido a la frecuencia con la que datos de diferentes grupos tienen mucha similitud, una vez que se realizan estas agrupaciones la subdivisión más cercana a la realidad se le da como el punto más óptimo para la ubicación de compensadores de potencia [23].

2 Marco Teórico.

2.1 Compensación de Potencia Activa y Reactiva.

La compensación de energía es un proceso en el cual se encarga de disminuir o eliminar por completamente la energía reactiva de las redes, ya que esta energía reactiva aparece por diferentes formas tales como el efecto capacitivo que existe en las redes de transmisión, la inducción que existe en los bobinados de motores y transformadores, equipos que inyectan energía reactiva entre otras formas [1].

La compensación de energía reactiva es a través de un proceso o sistema eléctrico en el cual consiste la instalación de capacitores o filtros armónicos a la red, esto se lo realiza para incrementar o subir el valor de la potencia reactiva con relación a la potencia activa nominal, la finalidad del sistema eléctrico planteado es que el factor de potencia debería llegar a un valor aproximado de 1, esto quiere decir que toda la potencia entregada a la red sería una potencia útil o eficaz [2].

Cuando se habla acerca de compensación de energía es porque existe un problema en el suministro de energía, con lo cual se da a entender que la potencia reactiva entregada da como consecuencia un mayor incremento de corriente.

esto en comparación a la potencia activa se puede deducir que el valor de corriente es muy elevada, enfocados en transmisión la corriente que pasa por las líneas es muy alta por lo cual se debe tomar en cuenta otros factores como el calibre del conductor [3], [4], protecciones entre otras cosas, por lo

cual para evitar el cambio de todo lo antes mencionado se realiza la compensación de energía.

Para aclarar el problema de una cantidad de energía reactiva considerable daremos como ejemplo un factor de potencia de 0.7 las pérdidas que se producen serían del 100 %, en cambio con un factor de potencia de 0.9 las pérdidas se reducen a un 25 %, con lo cual se puede decir que la compensación de energía es muy útil en sistemas eléctricos [5], [6].

También se destaca la realidad de una cierta necesidad que exista energía reactiva debido a componentes en los cuales la energía reactiva es útil como la inducción, pero lo ideal entonces sería que la energía suministrada tenga un factor de potencia que se acerque considerablemente a uno [7].

La compensación de energía se da tanto para transmisión y para distribución, en transmisión se lo realiza de manera que la potencia reactiva no tenga un nivel muy alto debido a que el efecto capacitivo que existe en las líneas pueda ocasionar algún accidente de descarga con otra línea por diferentes factores como: la oscilación del viento entre otros problemas esporádicos, [8], [9].

En cambio, la compensación de energía en distribución se da para que en nivel de consumidor tenga un buen servicio y no exista falla en equipos o en sistemas, por ejemplo, en redes soterradas a lo largo de un tramo también se da un efecto capacitivo, si el nivel de la potencia reactiva es muy alto podría ocasionar calentamiento y disminuiría la vida productiva del conductor [10], [11].

2.2 Tipos de Compensación.

Según las empresas eléctricas encargadas de la distribución de energía, tienen identificado un problema muy grande el cual es el costo de pérdidas en servicios operativos y las pérdidas en la red de distribución. Por lo cual se ha realizado una búsqueda de métodos y herramientas que ayuden a solucionar los problemas anteriormente mencionados [12], se describirán a continuación algunos métodos para solucionar aquellos problemas.

2.2.1 Compensación reactiva paralelo pura.

La función principal de este método es aumentar la eficiencia del factor de potencia, ya que en base a las fórmulas cuando la corriente disminuye existe una menor potencia por lo tanto una menor pérdida, además mejorara los niveles de tensión [13].

2.2.2 Compensación reactiva en serie.

Cuando se utiliza el método de compensación reactiva en serie, se disminuye en un gran margen la variación de voltaje y las pérdidas en la red eléctrica de distribución. Esto se da por la conexión en serie de la parte capacitiva a la red. Es el resultado de la compensación en serie ya que al estar conectado como su nombre mismo lo indica se da una auto-regulación de potencia reactiva la que está directamente proporcional a la corriente [14].

2.2.3 Maquinas Sincrónicas.

La generación de potencia reactiva en kVAr es proporcional a la excitación de la generadora, para abastecer la demanda de potencia reactiva y poder transferir a la red eléctrica de

distribución se necesita realizar una sobreexcitación de la máquina. Por este medio la maquina o el motor tendrá que funcionar con un rango muy amplio de regulación, también un nombre que se le da a este método es el de condensador sincrónico.

El campo eléctrico depende exclusivamente del nivel de excitación para que la amplitud del rango sea suficiente tanto para la parte capacitiva como inductiva. Es necesario indicar que el método de las maquinas sincrónicas tiene dos principales funciones: la primera es la que trabaja con capacitores a la cual se la denomina el método de sobre-excitación y la segunda función es aquella en la cual intervienen bobinas o una parte inductiva, por lo tanto, se la conoce como sub-excitación [14], [15].

En este método siempre existirá dos configuraciones, cuando esté sub-excitado se limitará por la estabilidad con la cual funciona la máquina, mientras que cuando este sobre-excitado la potencia va a disminuir en función de la temperatura.

2.2.4 SVC.

Compensador estático de potencia reactiva o SVC, su funcionamiento se determina por el uso de tiristores, inductancias y capacitancias, por lo cual son elementos principales en la electrónica de potencia.

Entrándose un poco más en el campo de la electrónica de potencia se la puede denominar una alternativa para problemas que ocurren en sistemas de transmisión como en sistemas de distribución [16]–[18]. Una gran diferencia del método SVC con los métodos mencionados anteriormente, los cuales solo se

encargan de absorber o generar potencia reactiva por medio de semiconductores conectados en serie o en paralelo a la red eléctrica de distribución o transmisión sin ser objetos que se puedan desplazar.

Este método se realiza en el sistema de compensación ya que aumenta o disminuye el valor y el margen de los niveles del condensador estático de kVAr [19], [20].

2.3 Métodos Para Encontrar la Óptima Ubicación de Compensación.

2.3.1 Algoritmo de búsqueda exhaustiva.

Es un algoritmo particular que se aplica para encontrar elementos con particularidades, por lo general se encuentran estos objetos en combinaciones o permutaciones. En el método general se basa en una lista de todas las posibles soluciones en una forma sistemática, también se revisan las mejores soluciones, apartando a las soluciones que no se puedan ejecutar, una vez finalizada la búsqueda se regresa a la solución más apta encontrada anteriormente [21].

2.3.2 Algoritmo K-NN (K Nearest Neighbourst).

El siguiente algoritmo se encarga de clasificar cada dato que aparezca en un grupo, también calcula la distancia del nuevo elemento con sus vecinos k y ordena las distancias de menor a mayor, se encontrara un grupo con mayores coincidencias y con distancias muy cortas, este algoritmo es de aprendizaje supervisado.

2.3.3 Función Multiobjetivo.

En el tipo de optimización multiobjetivo, las funciones objetivo

presentan un costo para optimizar, estas tienen como restricciones n parámetros, con estos parámetros deben optimizar m aptitudes y el problema general está dado por (1).

2.3.4 Redes Neuronales.

Una red neuronal eléctrica en un concepto abreviado es un modelo matemático dedicado a simular la estructura neuronal del ser humano, por lo cual por medio de esta red va a pasar información, también por su capacidad se la utiliza para realizar test, evaluaciones o pronosticar lo que pasa o va a pasar en las redes eléctricas [21].

2.4 Redes Neuronales.

Se realizaron los primeros estudios de redes neuronales en 1943 por Warren McCulloch y Walter Pitts, gracias a la demostración y valides de las redes neuronales hoy en día también se aplican en los sistemas eléctricos por las ventajas que se obtienen de las mismas, como su eficiente tiempo al implantarlas, diagnóstico de fallas, adaptación de tecnología VSLI (Integración a muy gran escala).

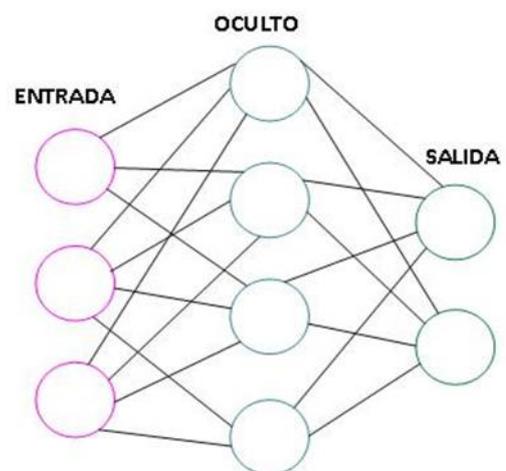


Figura 2. Redes neuronales

Una red neuronal se la define por tres factores importantes, los cuales son la arquitectura de red, función de transferencia y ley de aprendizaje. Estos factores están definidos siempre en función del problema.

Además, existen tres elementos básicos de una red neuronal los cuales son la capa de entrada, ocultas y la de salida, en donde la función que realiza la capa de entrada es de recibir información desde el exterior, la función de las capas ocultas es la comunicación entre la capa de entrada y de salida, la función de la capa de salida es brindar los resultados al exterior [22].

2.5 Topologías de Redes Neuronales.

Existen dos topologías principales en las redes neuronales las cuales son mono capa y multicapa, en donde las redes mono capa realizan conexiones pertenecientes a la misma capa o en palabras más simples realizan una auto conexión.

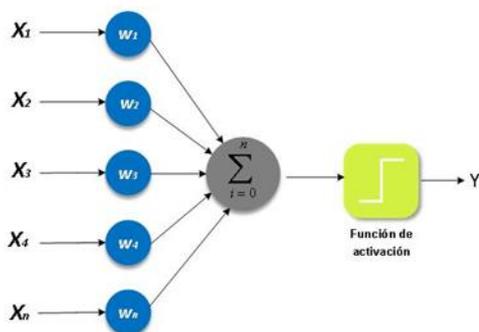


Figura 3. Red neuronal monomodo

Por otro lado, las redes multicapa tienen un conjunto agrupado de neuronas en distintas capas y para distinguir el nivel al que pertenece la neurona, se realiza un análisis de las señales que llegan a la capa de entrada.

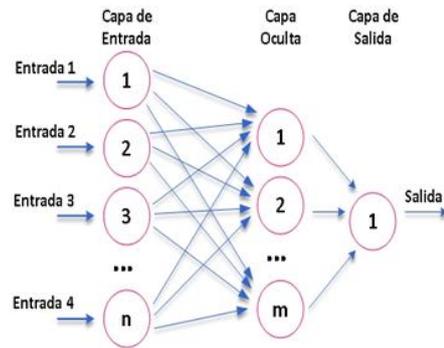


Figura 4. Red neuronal multimodo

2.6 Tipos de redes neuronales.

En las redes neuronales existen dos tipos de mecanismo de aprendizaje, los cuales son redes con aprendizaje supervisado y con aprendizaje no supervisado [23].

2.6.1 Redes con aprendizaje supervisado.

El aprendizaje supervisado se desarrolla por una enseñanza controlado o supervisada como su nombre mismo lo dice, por lo cual se desarrolla una respuesta que se genera en la entrada o al inicio de la red.

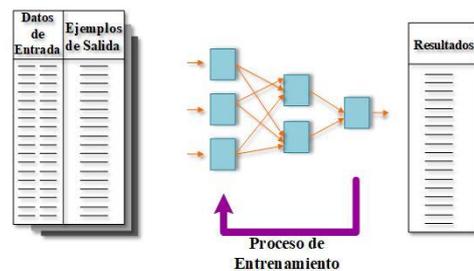


Figura 5. Red neuronal aprendizaje supervisado.

Existe una subdivisión en las redes de aprendizaje supervisado las cuales son tres, la primera es el aprendizaje por corrección de error (backpropagation) la cual es la encargada de ajustar los pesos entre las conexiones a través de un indicador de error entre el valor esperado y el valor de salida, para encontrar dicho error se

realizan cuatro ecuaciones, las cuales se detallan a continuación.

$$d_j^l = \frac{dC}{da_j^l} \sigma^l(z - j^l) \quad (1)$$

Donde:

$\frac{dC}{da_j^l}$ es la expresión de medir rápido el coste de la función de salida.

d_j^l mide la variación de activación d.

$$d = ((w^{l+1})^T d^{l+1}) \cdot \sigma^l(z^L) \quad (2)$$

Donde:

$(w^{l+1})^T$ es la transposición de la matriz de peso.

$d * 1^{l+1}$ es el error.

$\cdot \sigma^l(z^L)$ es el producto Hadamard.

$$d * 1_j^l = \frac{dC}{db_j^l} \quad (3)$$

Donde:

$d * 1_j^l$ es el error.

$\frac{dC}{db_j^l}$ es la tasa de cambio.

$$\frac{dC}{dw_{jk}^l} = (a_k^{l-1} - d * 1_j^l) \quad (4)$$

El segundo es el aprendizaje por refuerzo el cual es un poco más lento, pero consta de un supervisor el cual indica a través de una señal de refuerzo si el resultado de salida se ajusta al valor esperado en la salida.

El tercero es un aprendizaje estocástico el cual se encarga de realizar una serie de cambios aleatorios en los pesos y con cada cambio realiza una evaluación en el efecto causado tomando en consideración el objetivo al que se quiere alcanzar [24], [25].

2.6.2 Redes con aprendizaje no supervisado.

Como su nombre lo indica esta no necesita ninguna influencia externa para realizar ajustes en los pesos de las conexiones de las neuronas, el principal

objetivo de estas redes es encontrar características, categorías, correlaciones, regularidades e irregularidades que se pueden manifestar en los datos de la entrada [26].

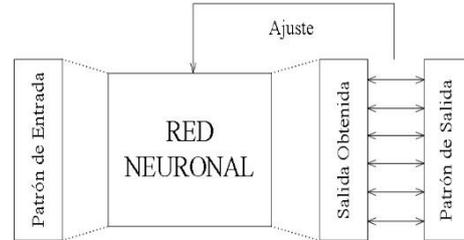


Figura 6. Red neuronal con aprendizaje no supervisado.

En las redes de aprendizaje no supervisado también existe dos subdivisiones para una mejor especificación.

La primera es el aprendizaje Hebbiano el cual se encarga de extraer familiaridades o características de los valores de la entrada, esta subdivisión se encarga de ajustar los pesos en base a la correlación de los valores con los cuales se realizan la activación de un numero de neuronas entrelazadas [27].

Al segundo se lo determina aprendizaje cooperativo o competitivo el cuál es el encargado de la competición de las neuronas con la finalidad de alcanzar un objetivo dispuesto, también se puede decir que las neuronas compiten entre ellas para activarse por lo que se puede determinar que las neuronas perdedoras van a tener valores de respuestas muy pequeños [28].

Además, existen diversos tipos de redes neuronales más relevantes que se aplican en el sector eléctrico, las cuales se describirán a continuación.

2.6.3 Redes neuronales de predicción.

Las redes neuronales de predicción forman un principal instrumento para una aproximación casi exacta de ecuaciones no lineales.

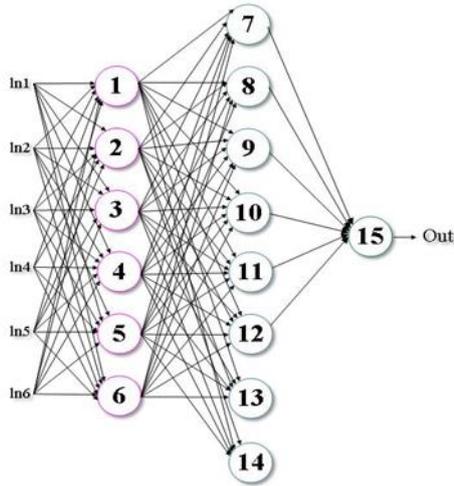


Figura 7. Red neuronal de predicción.

El uso de las redes neuronales de predicción es específicamente útil cuando se modelan fenómenos complejos, en donde no existen relación con funciones no lineales entre sus variables. Una de las ventajas de la red neuronal de predicción es la metodología con la que se aplica, la cual consiste en eliminar hipótesis lineales [29].

Cuando existen bases de datos que almacenan demasiada información privada o cifrada que evita que la red neuronal tome una decisión basada en esa información. La red neuronal de predicción o clasificación es una manera de analizar datos los cuales, los cuales se usan para identificar un método o algoritmo que permita la clasificación de los datos más relevantes, con lo cual se puede determinar cómo sería el

comportamiento en un futuro inmediato de los mismos [30].

3 Planteamiento del Problema.

3.1 Sistemas de Prueba.

En los sistemas en los cuales se va a basar el planteamiento del problema son sistemas diseñados especialmente para pruebas de flujos de potencia, pero en este caso el uso de los sistemas de 33 y 34 barras se los usara para el desarrollo de encontrar la ubicación óptima y la aplicación de redes neuronales en estos sistemas.

3.1.1 Sistema IEEE de 34 Barras.

En la figura 7 se puede visualizar el sistema de distribución de 34 barras en el cual se analizará la óptima ubicación para la compensación de potencia utilizando además algoritmos de redes neuronales y encontrar las diferencias entre los sistemas de transmisión de 33 barras y el sistema de distribución de 34 nodos.

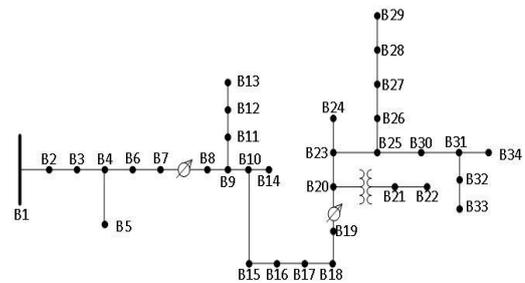


Figura 8. Sistema de prueba de 34 barras.

3.1.2 Sistema IEEE de 33 Barras.

En la figura 8 se puede visualizar el sistema de transmisión de 33 barras en el cual se analizará la óptima ubicación para la compensación de potencia utilizando además algoritmos de redes neuronales y encontrar las diferencias entre los sistemas de transmisión de 33

barras y el sistema de distribución de 34 nodos.

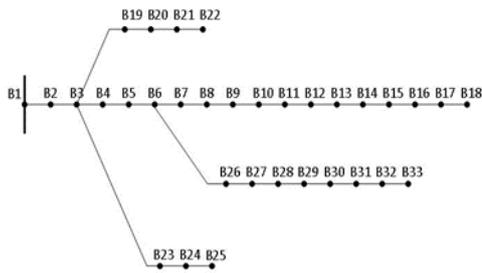


Figura 9. Sistema de prueba de 33 barras.

3.2 Generación Distribuida

Como bien se sabe la implementación de la generación distribuida se da en base al cambio energético o tratando de implantar la idea de que cada consumidor de energía puede abastecerse, de esta idea se empiezan a dar casos en donde se implementan paneles fotovoltaicos en viviendas, se detallara a continuación los parámetros más importantes en un panel fotovoltaico.

La metodología se divide en tres partes, la primera es la recolección de datos en la cual se añaden todos los datos como la radiación, la temperatura, la potencia generada, el promedio de energía consumida durante un periodo y se detalla una resistencia variable.

La segunda fase es el procesamiento de la información, tomar cada variable y realizar un sistema de prueba en donde se encuentran variables tales como la radiación y temperatura realizando pequeños ajustes en los parámetros para encontrar la potencia ideal del panel.

La tercera fase es la simulación y el análisis del panel solar en donde se van

a desarrollar pruebas y se ejecutaran para encontrar la corriente de saturación que se va a producir y esto se determina a través de las siguientes ecuaciones. los parámetros más importantes en un panel fotovoltaico.

$$I_{cel} = I_{ph} - I_d - I_{sh} \quad (5)$$

Donde:

I_{cel} es la corriente generada

I_{ph} es la corriente fotogenerada

$$I_{cel} = I_{ph} - I_0 \left[e^{\frac{q(V + I_{cel}R_s)}{KT_cA}} - 1 \right] \quad (6)$$

Donde:

I_0 es la corriente de saturación.

q es la carga del electrón.

V es el voltaje de la celda solar.

K es la constante de Boltzmann.

T_c temperatura de operación de la celda.

A es el factor de idealidad.

Los valores utilizados en el presente trabajo de potencia reactiva de las unidades de generación (panel fotovoltaico) son los representa en la tabla 1:

	Potencia activa (kW)
Panel fotovoltaico 1	200
Panel fotovoltaico 2	300

Tabla 1. Datos de potencia de unidades de generación

3.3 Óptima Ubicación Mediante Redes Neuronales.

Para determinar la óptima ubicación de unidades de generación distribuida en un sistema de distribución IEEE mediante el método de redes neuronales, en necesario el uso del software MATLAB simulink en el cual

se simulará los sistemas de distribución IEEE de 33 y 34 barras.

Se agregará la unidad o unidades de generación con su respectiva potencia, en cada número de barra dependiendo el caso de estudio.

3.3.1 Descripción del algoritmo con una sola unidad de generación.

En este caso de estudio se agrega una unidad de generación en la barra 1 del sistema de distribución IEEE, obteniendo los primeros 33 valores de voltaje de las barras. El proceso se repite en cada una de las barras hasta completar todas las barras obteniendo una matriz de 33x33.

Con la obtención de nuestros valores pu de voltajes y con una desviación objetivo de valor 1, se determina la desviación estándar y nuestro CERO (con la cual se realizará la clasificación) en cada uno de los casos en que se va agregando la unidad de generación.

3.3.2 Descripción del algoritmo con dos unidades de generación.

Para este caso de estudio se escogen 8 barras con los valores de voltaje más bajos, a los cuales se realizan combinaciones de dos unidades de generación (UDG) en el sistema de distribución IEEE por cada caso.

El proceso realizado en este caso de estudio será idéntico al mencionado anteriormente con una sola unidad de generación, con la diferencia que en esta ocasión tendremos una matriz de 29x33 debido al número de combinaciones.

Paso 1	Ingreso y lectura de inputs (valores de perfiles de voltaje en pu). Clasificados en: excelente, bueno, regular, malo y nulo.
Paso 2	Ingreso y lectura de targets (la cantidad total de subcasos en cada clasificación será el número de salidas correspondientes).
Paso 3	Ingreso de todos los parámetros de la red neuronal (Tabla3).
Paso 4	Análisis de resultados.
Paso 5	Fin.

Tabla 2. Óptima ubicación de UDG en sistemas de distribución mediante RNA en MATLAB

Parámetros	Descripción
Patrón de la red	Redes de retroalimentación que permite ingresar el número de neuronas y se entrenan para clasificar los inputs.
Variable de entrenamiento relacionado al backpropagation	Es el algoritmo de retropropagación que actualiza los valores de los pesos.
Épocas	Se crea el número máximo de épocas para el entrenamiento.
Verificación de fallas	Escoge el valor mínimo global del error.
Error mínimo permitido	Es el error mínimo permitido al que puede llegar la red.
Peso de factor de aprendizaje	Factor de aprendizaje de los pesos iniciales.

Tabla 3. Parámetros de la red neuronal en MATLAB

La Tabla 3 presenta los principales parámetros dentro de una red neuronal artificial para su entrenamiento y correcto funcionamiento.

4 Casos de estudio.

La ecuación que se utiliza para encontrar los valores de categoría de clasificación se describe como:

$$\Sigma = |(B - B')| \quad (7)$$

Donde:

B = Valores de los voltajes de las barras en pu.

B' = Desviación objetivo

Para la resolución del problema utilizaremos $B'=1$

Para identificar el tipo de clasificación en el software MATLAB se realizará de la siguiente manera:

Clase 1: nulo

Clase 2: malo

Clase 3: regular

Clase 4: bueno

Clase 5: excelente

Esta explicación ayuda a entender cómo se clasifica los resultados de una red neuronal en lo cual se determina la más adecuada a través de un código binario.

4.1 Escenario con una sola generación.

4.1.1 Caso 1:

Óptima ubicación de una unidad de generación (panel fotovoltaico) de 200kW en un sistema de distribución IEEE de 33 barras.

Paso 1	Se realiza la lectura de perfiles de voltajes sin agregar generación.
--------	-----------------------------------------------------------------------

Paso 2	Se agrega la unidad de generación en una barra PV, obtenemos los valores de voltajes en cada barra.
Paso 3	Obtención de datos para la entrada de la red neuronal.
Paso 4	Obtención de datos de salida de la red neuronal según la cantidad total de subcasos en cada clasificación.

Tabla 4. Obtención de datos del sistema de distribución IEEE de 33 barras

Los pasos de la tabla 4 se repiten en todos los casos de estudio, cambiando las características de las redes neuronales en cada caso.

Las principales características de la red neuronal para el presente caso de estudio son:

Parámetros	Valor
Número de neuronas para la capa oculta	4
Número de épocas	48
Número para la verificación de fallas	25
Valor del error mínimo permitido	1e-29

Tabla 5. Parámetros de la óptima ubicación Caso 1

La tabla 5 muestra los parámetros que se utilizó para una efectividad excelente en el entrenamiento de la red para este caso de estudio.

4.1.2 Caso2:

Óptima ubicación de una unidad de generación (panel fotovoltaico) de

300kW en un sistema de distribución IEEE de 33 barras.

Las principales características de la red neuronal para el presente caso de estudio son:

Parámetros	Valor
Número de neuronas para la capa oculta	4
Número de épocas	42
Número para la verificación de fallas	9
Valor del error mínimo permitido	1e-29

Tabla6. Parámetros de la óptima ubicación Caso 2.

La tabla 6 muestra los parámetros que se utilizó para una efectividad excelente en el entrenamiento de la red para este caso de estudio.

4.2 Escenario con dos generaciones.

4.2.1 Caso3:

Óptima ubicación de dos unidades de generación de 200kW en un sistema de distribución de 33 barras.

Las principales características de la red neuronal para el presente caso de estudio son:

Parámetros	Valor
Número de neuronas para la capa oculta	3
Número de épocas	58
Número para la verificación de fallas	26
Valor del error mínimo permitido	1e-29

Tabla 7. Parámetros de la óptima ubicación Caso 3.

La tabla 7 muestra los parámetros que se utilizó para una efectividad excelente en el entrenamiento de la red para este caso de estudio.

4.2.2 Caso4:

Óptima ubicación de dos unidades de generación de 300kW en un sistema de distribución de 33 barras.

Las principales características de la red neuronal para el presente caso de estudio son:

Parámetros	Valor
Número de neuronas para la capa oculta	4
Número de épocas	70
Número para la verificación de fallas	22
Valor del error mínimo permitido	1e-29

Tabla8. Parámetros de la óptima ubicación Caso 4.

La tabla 8 muestra los parámetros que se utilizó para una efectividad excelente en el entrenamiento de la red para este caso de estudio.

5 Análisis de resultados.

A continuación, se presenta los diferentes resultados para los casos de estudios realizados en este artículo, donde se puede apreciar diferentes parámetros como el porcentaje de efectividad de entrenamiento, el error cuadrático medio, mejor validación, etc.

5.1 Caso 1

En la figura 9 se puede determinar que existió un lapso muy pequeño hasta la época 5 de subidas y bajadas de error cuadrático medio, luego se aprecia un desplome del error hasta llegar a la

mejor validación que fue en la época 47 con un error cuadrático medio de $3.0542e-21$.

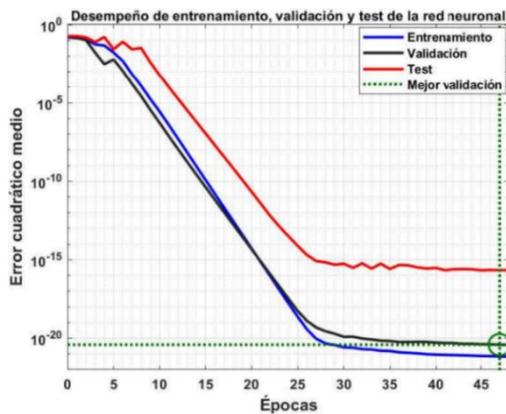


Figura 10. Sistema de prueba 33 barras a 200kV

En la figura 10 se observa que el gradiente de error llegó hasta un valor de $1.4613e-20$ en la época 48, quiere decir que el error no alcanzó a llegar hasta el error máximo permitido que es de $1e-29$ y se validó en la iteración 1 ya que en las demás iteraciones el error va incrementando.

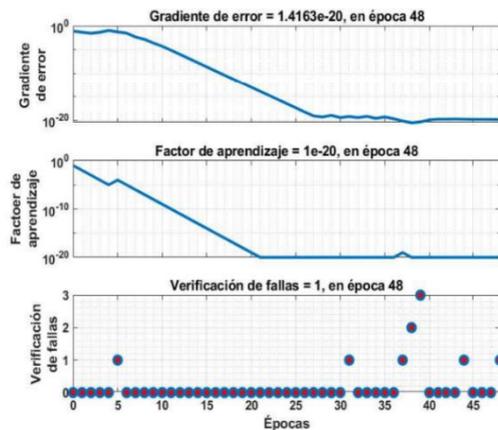


Figura 10. Estado del entrenamiento de 33 barras a 200kV.

En la matriz de entrenamiento figura 11 se puede destacar que la red tuvo una eficiencia del 100% de entrenamiento y clasificación, observando así que: en la clase 1 existió un 45.5% de clasificación de aprendizaje de todos los inputs, en la clase 2 un 33.3% de aprendizaje, en la clase 3 una clasificación de aprendizaje de 12.1%, en la clase 4 un aprendizaje

del 3% y en la clase 5 existió un aprendizaje del 6.1%, llegando a un aprendizaje total del 100% en nuestro sistema de 33 barras a 200kV.

Matriz total de confusión

Clase de salida	1	2	3	4	5	
1	15 45.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
2	0 0.0%	11 33.3%	0 0.0%	0 0.0%	0 0.0%	100%
3	0 0.0%	0 0.0%	4 12.1%	0 0.0%	0 0.0%	100%
4	0 0.0%	0 0.0%	0 0.0%	1 3.0%	0 0.0%	100%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 6.1%	100%
	100%	100%	100%	100%	100%	100%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
	1	2	3	4	5	
	Clase objetivo					

Figura 11. Matriz de entrenamiento de 33 barras a 200 kV

Subcaso de estudio	Valor de desviación objetivo del sistema	Clase esperada	Clasificación de la red
5	0.9587	Excelente	[0 0 0 0 1]
18	0.9999	Nulo	[1 0 0 0 0]
2	1.10186	Bueno	[0 0 0 1 0]
15	1.0206	Bueno	[0 0 0 1 0]
7	1.0006	Nulo	[1 0 0 0 0]

Tabla9. Comprobaciones de los subcasos de un sistema IEEE de 34 barras

En la tabla 9 comprobamos que la RNA propuestas previamente en el sistema IEEE de 33 barras; en el sistema distribución IEEE de 34 barras, cumple con su función objetivo. Obteniendo de manera satisfactoria todas las clases esperadas mediante su clasificación.

Subcaso de estudio	Valor de desviación objetivo del sistema	Clase esperada	Clasificación de la red
12	1.0047	Nulo	[1 0 0 0 0]
23	1.0232	Excelente	[0 0 0 0 1]
9	0.9905	Malo	[0 1 0 0 0]
1	0.985	Regular	[0 0 1 0 0]
30	0.9905	Malo	[0 1 0 0 0]

Tabla10. Comprobaciones de los subcasos de un sistema IEEE de 34 barras

En la tabla 10 comprobamos que la RNA propuestas previamente en el sistema IEEE de 33 barras; en el sistema distribución IEEE de 34 barras, cumple con su función objetivo. Obteniendo me manera satisfactoria todas las clases esperadas mediante su clasificación.

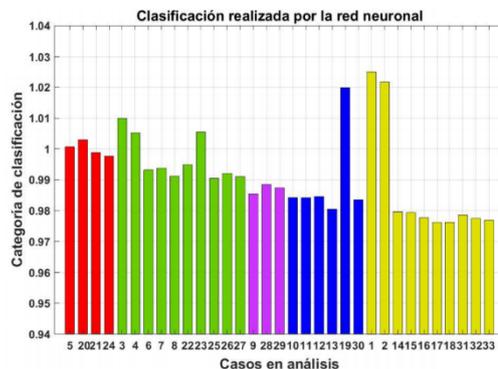


Figura 16. Clasificación realizada por RNA de 33 barras a 300 kv

Finalmente, la figura 16 muestra un escenario total de todas clasificaciones, obteniendo así: clase 1 con 4 subcasos, la clase 2 con 10 subcasos, la clase 3 con 3 subcasos, para la clase 4 tenemos 6 subcasos y para la clase 5 con 10 subcasos.

5.3 Caso 3.

En la figura 17 de puede determinar que existió un lapso muy pequeño hasta la época 18 de subidas y bajadas de error cuadrático medio, luego se aprecia un desplome del error hasta llegar a la mejor validación que fue en la época 43 con un error cuadrático medio de $2.0117e-19$.

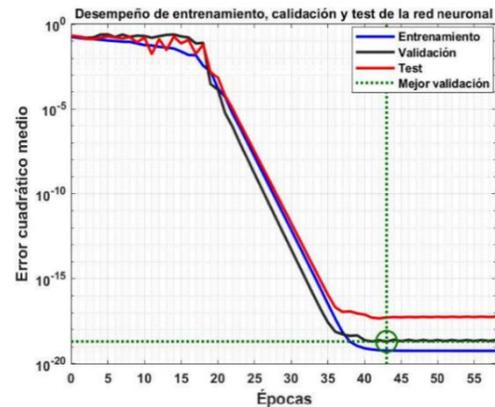


Figura 17. Sistema de prueba 33 barras a 300kv

En la figura 18 se observa que el gradiente de error llego hasta un valor de $1.4197e-18$ en la época 58, quiere decir que el error no alcanzo a llegar hasta el error máximo permitido que es de $1e-29$ y se validó en la iteración 15 ya que en las demás iteraciones el error va incrementando.

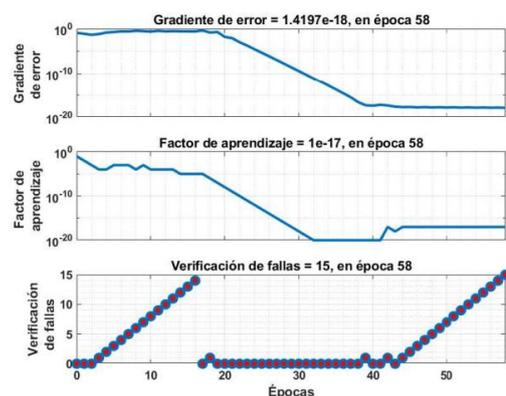


Figura 18. Estado de entrenamiento de 33 barras a 200kv combinado

En la matriz de entrenamiento figura 19 se puede destacar que la red tuvo una eficiencia del 100% de entrenamiento y clasificación, observando así que: en la clase 1 existió un 17.2% de clasificación de aprendizaje de todos los inputs, en la clase 2 un 10.3% de aprendizaje, en la clase 3 una clasificación de aprendizaje de 10.3%, en la clase 4 un aprendizaje del 31% y en la clase 5 existió un aprendizaje del 31%, llegando a un aprendizaje total del 100% en nuestro sistema de 33 barras a 200kV combinado.

Clase de salida	1	2	3	4	5	
1	5 17.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	3 10.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	3 10.3%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	9 31.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 31.0%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	1	2	3	4	5	
	Salida objetivo					

Figura 19. Matriz de entrenamiento de 33 barras a 200kV combinado

Subcaso de estudio	Valor de desviación objetivo del sistema	Clase esperada	Clasificación de la red
14	0.9997	Nulo	[1 0 0 0 0]
21	0.9218	Excelente	[0 0 0 0 1]
29	0.9611	Excelente	[0 0 0 0 1]
9	0.9623	Bueno	[0 0 0 1 0]
16	0.9637	Regular	[0 0 1 0 0]

Tabla11. Comprobaciones de los subcasos de un sistema IEEE de 34 barras

En la tabla 11 comprobamos que la RNA propuestas previamente en el sistema IEEE de 33 barras; en el sistema distribución IEEE de 34 barras, cumple con su función objetivo. Obteniendo me manera satisfactoria todas las clases esperadas mediante su clasificación.

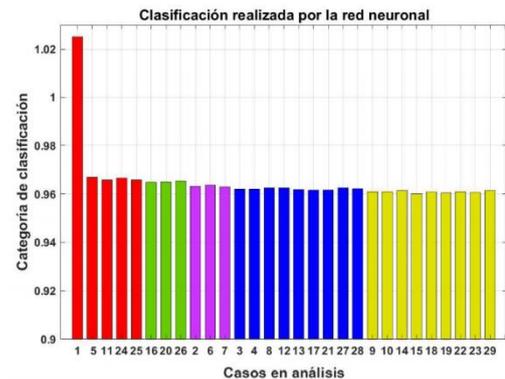


Figura 20. Clasificación realizada por RNA de 33 barras a 200 kV combinada

Finalmente, la figura 20 muestra un escenario total de todas clasificaciones, obteniendo así: clase 1 con 5 subcasos, la clase 2 con 3 subcasos, la clase 3 con 3 subcasos, para la clase 4 tenemos 9 subcasos y para la clase 5 con 9 subcasos.

5.4 Caso 4

En la figura 21 de puede determinar que existió un lapso muy pequeño hasta la época 12 de subidas y bajadas de error cuadrático medio, luego se aprecia un desplome del error hasta llegar a la mejor validación que fue en la época 49 con un error cuadrático medio de 3.1562-22.

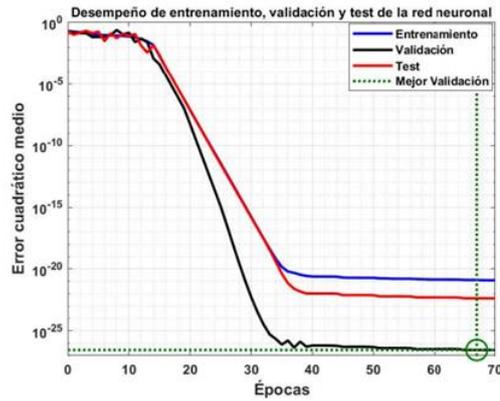


Figura 21. Sistema de prueba 33 barras a 300kV combinado

En la figura 22 se observa que el gradiente de error llego hasta un valor de $4.4985e-21$ en la época 70, quiere decir que el error no alcanzo a llegar hasta el error máximo permitido que es de $1e-29$ y se validó en la iteración 3 ya que en las demás iteraciones el error va incrementando.

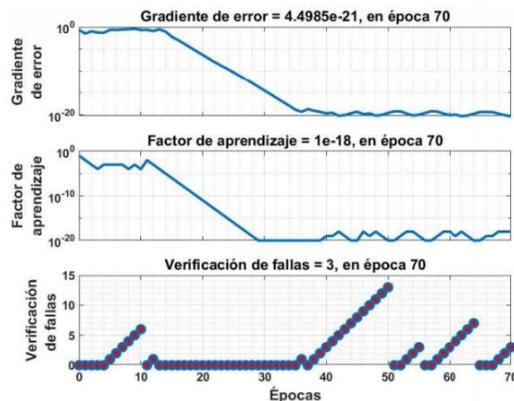


Figura 22. Estado de entrenamiento de 33 barras a 300kV combinado

En la matriz de entrenamiento figura 23 se puede destacar que la red tuvo una eficiencia del 100% de entrenamiento y clasificación, observando así que: en la clase 1 existió un 17.2% de clasificación de aprendizaje de todos los inputs, en la clase 2 un 10.3% de aprendizaje, en la clase 3 una clasificación de aprendizaje de 6.9%, en la clase 4 un aprendizaje del 37.9% y en la clase 5 existió un aprendizaje del 27.6%, llegando a un aprendizaje total del 100% en nuestro

sistema de 33 barras a 300kV combinado.

Matriz total de confusión

Clase de salida	1	2	3	4	5	
1	5 17.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	3 10.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	2 6.9%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	11 37.9%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 27.6%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	1	2	3	4	5	

Clase objetivo

Figura 23. Matriz de entrenamiento de 33 barras a 300kV combinado

Subcaso de estudio	Valor de desviación objetivo del sistema	Clase esperada	Clasificación de la red
10	0.9234	Excelente	[0 0 0 0 1]
5	0.9377	Nulo	[1 0 0 0 0]
7	0.9342	Nulo	[1 0 0 0 0]
23	0.9322	Bueno	[0 0 0 1 0]
22	0.9321	Bueno	[0 0 0 1 0]

Tabla12. Comprobaciones de los subcasos de un sistema IEEE de 34 barras

En la tabla 12 comprobamos que la RNA propuestas previamente en el sistema IEEE de 33 barras; en el sistema distribución IEEE de 34 barras, cumple con su función objetivo. Obteniendo me manera satisfactoria todas las clases esperadas mediante su clasificación.

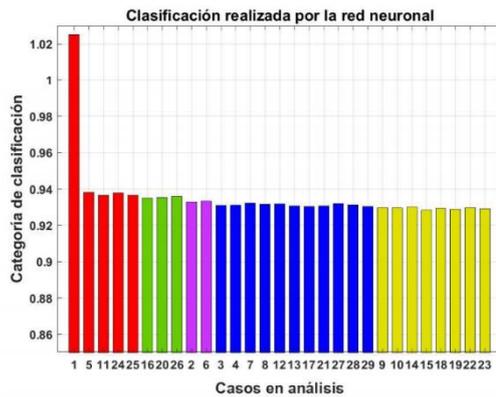


Figura 24. Clasificación realizada por RNA de 33 barras a 300 kV combinada

Finalmente, la figura 20 muestra un escenario total de todas clasificaciones, obteniendo así: clase 1 con 5 subcasos, la clase 2 con 3 subcasos, la clase 3 con 2 subcasos, para la clase 4 tenemos 11 subcasos y para la clase 5 con 8 subcasos.

6 Conclusiones

Se puede llegar a la conclusión que en los sistemas de distribución IEEE tanto de 33 y 34 barras se comprueba a través del software Matlab la efectividad del método utilizado para determinar la óptima ubicación de unidades de generación dejando en claro que el método de redes neuronales artificiales es uno de los métodos más viables para la óptima ubicación ya que se logró crear una matriz de efectividad del 100%.

Para obtener una excelente efectividad de entrenamiento de la red neuronal en este artículo, depende de tres parámetros fundamentales: el número de neuronas de 3 a 5, número de épocas de 40 a 70 y número de verificación de fallas de 5 a 30. Cuyos valores son modificables y distintos dependiendo el caso de estudio o problema propuesto para el entrenamiento de la red.

En el análisis de resultados se observa una diferencia notable en las clasificaciones que realiza la red neuronal en los distintos casos de estudio al ir aumentando la potencia activa, determinando así que en el caso de estudio 1: las clases 4 (Bueno) tiene 1 subcaso, la clase 5 (Excelente) tiene 2 subcasos. Y en el caso de estudio 2 donde se añade una mayor potencia se observa la mejora de subcasos: clase 4 (Bueno) con 6 subcasos y la clase 5 (Excelente) con 10 subcasos.

7 Referencias

- [1] D. Yi, L. Chongru, X. Tian, and H. Yongxiu, "The power output characteristics of Jiuquan wind power base and its reactive power compensation," *Asia-Pacific Power Energy Eng. Conf. APPEEC*, no. 51190103, 2013
- [2] G. W. Chang and W. C. Chen, "A new reference compensation voltage strategy for series active power filter control," *IEEE Trans. Power Deliv.*, vol. 21, no. 3, pp. 1754–1756, 2006.
- [3] G. Yang, L. Li, and X. Zhang, "Numerical and Experimental Analysis of CSR of Transformer Type for Bidirectional Reactive Power Compensation," *IEEE Trans. Appl. Supercond.*, vol. 26, no. 4, 2016.
- [4] Z. Ye, "Three-phase reactive power compensation using a single-phase AC/AC converter," *IEEE Trans. Power Electron.*, vol. 14, no. 5, pp. 816–822, 1999.
- [5] Y. Wang, G. Joos, and H. Jin, "DC-side shunt-active power filter for phase-controlled

- magnet-load power supplies,” *IEEE Trans. Power Electron.*, vol. 12, no. 5, pp. 765–771, 1997.
- [6] A. Javadi, A. Hamadi, L. Woodward, and K. Al-Haddad, “Experimental Investigation on a Hybrid Series Active Power Compensator to Improve Power Quality of Typical Households,” *IEEE Trans. Ind. Electron.*, vol. 63, no. 8, pp. 4849–4859, 2016.
- [7] M. E. El-Hawary, “Power engineering letters,” *IEEE Power Eng. Rev.*, vol. 22, no. 10, p. 43, 2002.
- [8] S. Electric, “Capítulo E La compensación de la energía reactiva,” p. 86, 2002.
- [9] S. Campo, “Estudio y cálculo de compensación de la energía reactiva en una planta industrial,” p. 332, 2014.
- [10] K. Nakamura, Y. Yamada, R. Nono, T. Ohinata, K. Arimatsu, and O. Ichinokura, “A Novel 3-D Concentric-Winding-Type Three-Phase Variable Inductor for Reactive Power Compensation in Electric Power Systems,” *IEEE Trans. Magn.*, vol. 53, no. 11, pp. 2015–2018, 2017.
- [11] L. Liu, H. Li, Y. Xue, and W. Liu, “Reactive power compensation and optimization strategy for grid-interactive cascaded photovoltaic systems,” *IEEE Trans. Power Electron.*, vol. 30, no. 1, pp. 188–202, 2015.
- [12] K. Kunisch and G. Stadler, “Generalized Newton methods for the 2D-Signorini contact problem with friction in function space,” *Math. Model. Numer. Anal.*, vol. 39, no. 4, pp. 827–854, 2005.
- [13] V. K. Chandrakar and A. G. Kothari, “Optimal location for line compensation by shunt connected FACTS controller,” *Proc. Int. Conf. Power Electron. Drive Syst.*, vol. 1, pp. 151–156, 2003.
- [14] H. Jiang, M. He, L. Liu, H. Ji, and D. Shan, “Reactive power compensation devices optimization based on improved ant colony algorithm,” *Proc. - Int. Conf. Electr. Control Eng. ICECE 2010*, pp. 1523–1526, 2010.
- [15] S. A. Jumaat, I. Musirin, M. M. Othman, and H. Mokhlis, “Optimal location and sizing of SVC using particle swarm optimization technique,” *Proc. - 1st Int. Conf. Informatics Comput. Intell. ICI 2011*, pp. 312–317, 2011.
- [16] “Compensación de Energía Reactiva y Filtrado de Armónicos La web donde encontrarás toda la información que necesitas sobre Schneider Electric,” 2019.
- [17] H. R. Daniel Arturo, “Análisis del proyecto de compensación de energía reactiva en baja tensión, implementado por Electronoroeste SA,” 2019.
- [18] R. Arias Quispe, “Compensación de energía reactiva,” *Cite Energía*, p. 5, 2016, [Online]. Available: <http://www.citeenergia.com.pe/wpcontent/uploads/2016/09/Ing.-Rosinaldo-Arias-Quispe.pdf>.
- [19] P. Pourbeik, R. J. Koessler, W. Quaintance, and W. Wong, “Performing comprehensive voltage stability studies for the determination of optimal

- location, size and type of reactive compensation,” *2006 IEEE Power Eng. Soc. Gen. Meet. PES*, no. 919, p. 27606, 2006.
- [20] J. V. Bedón, “Óptima Compensación Fija De Potencia En Redes Eléctricas De Distribución Basada En Escenarios De Demanda Residencial,” p. 37, 2020.
- [21] S. I. Sayegh, “Neural Networks to Acoustic Screening,” pp. 472–477, 1992.
- [22] M. Karthik and K. Gomathi, “Dynamic neural network based parametric modeling of PEM fuel cell system for electric vehicle applications,” *2014 Int. Conf. Adv. Electr. Eng. ICAEE 2014*, 2014.
- [23] S. W. Huang, H. M. Cheng, and S. F. Lin, “Improved Imaging Resolution of Electrical Impedance Tomography Using Artificial Neural Networks for Image Reconstruction,” *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 1551–1554, 2019.
- [24] B. Li, Y. Shen, and L. Li, “Electric heating cable fault locating system based on neural network,” *5th Int. Conf. Nat. Comput. ICNC 2009*, vol. 2, no. 07, pp. 43–47, 2009.
- [25] S. Martin and C. T. M. Choi, “Nonlinear Electrical Impedance.
- [26] E. Andrade, “Estudio de los principales tipos de redes neuronales y las herramientas para su aplicación,” p. 152, 2013.
- [27] P. Larrañaga, “Tema 8. Redes Neuronales,” pp. 1–19.
- [28] G. X. Carpio Suarez, P. A. Daga López, and P. D. Robles Lovato, “Aplicación de una red neuronal a un sistema eléctrico de distribución mediante el análisis de comportamiento de su carga en bajo voltaje,” p. 102, 2019.
- [29] J. M. Ruiz, “Neuronales Artificiales,” vol. 59, pp. 345–358, 2003.
- [30] G. Keifer and F. Effenberger, *REDES ARTIFICIALES*, vol. 6, no. 11. 1967.
- [31] M. Jaramillo and L. Tipán, “Comparative analysis of DG units against Capacitive banks in a micro-grid as an alternative for voltage profile enhancement,” in *2020 IEEE International Conference on Computing, Power and Communication Technologies (GUCON)*, 2020, pp. 261–267.

8. ESTADO DEL ARTE

DATOS			TEMÁTICA						FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO						RESTRICCIONES DEL PROBLEMA					PROPUESTAS PARA RESOLVER EL PROBLEMA					SOLUCIÓN PROPUESTA												
ITEM	AÑO	TÍTULO DEL ARTÍCULO	CITAS	ÓPTIMA UBICACIÓN	COMPENSADORES REACTIVOS	UBICACIÓN ÓPTIMA POR RN	METODOS	REDES NEURONALES	FLUJO EN MATLAB	MAXIMIZACIÓN DEL LUGAR EXACTO	MINIMIZACIÓN DE LUGARES OPTIMOS	UBICACIÓN ÓPTIMA DE COMPENSADORES	METODO REDES	TIPOS DE REDES	FORMAS DE COMPENSACION	MATRIZ DE EFICACIA	TIEMPO	ENRUTAMIENTO	TIPO DE NEURONA	POLICAPA	MONOCAPA	UBICACIÓN OPTIMA	SISTEMAS DE DISTRIBUCION	SISTEMA CON 200kV	SISTEMA CON 300kV	NUMEROS DE NEURONA	REDES NEURONALES	MATRIZ DE ENTRENAMIENTO HEURÍSTICAS o METAHEURÍSTICAS	UBICACIÓN ÓPTIMA	MATRIZ DE EFICIENCIA AL 100	CASOS CON 200kV	CASOS CON 300kV	RESULTADOS ESPERADOS	UBICACIÓN DE COMPENSADORES	FACTOR DE APRENDIZAJE		
1	2019	Análisis del proyecto de compensación de energía reactiva en baja tensión, implementado por Electronoroeste SA	11	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
2	2019	Compensación de Energía Reactiva y Filtrado de Armónicos La web donde encontrarás toda la información que necesitas sobre Schneider Electric	12	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3	2014	Estudio y calculo de compensación de la energía reactiva en una planta industrial .	9	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
4	2012	Capítulo E La compensación de la energía reactiva	2	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
5	2016	Compensación de energía reactiva	295	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
6	2002	Power engineering letters	126	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
7	2006	A new reference compensation voltage strategy for series active power filter control	112	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
8	1997	DC-side shunt-active power filter for phase-controlled magnet-load power supplies	203	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
9	2013	The power output characteristics of Jiuquan wind power base and its reactive power compensation	156	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
10	2016	Experimental Investigation on a Hybrid Series Active Power Compensator to Improve Power Quality of Typical Households	31	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
11	2017	A Novel 3-D Concentric-Winding-Type Three-Phase Variable Inductor for Reactive Power Compensation in Electric Power Systems	13	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

8.1 Resumen de indicadores

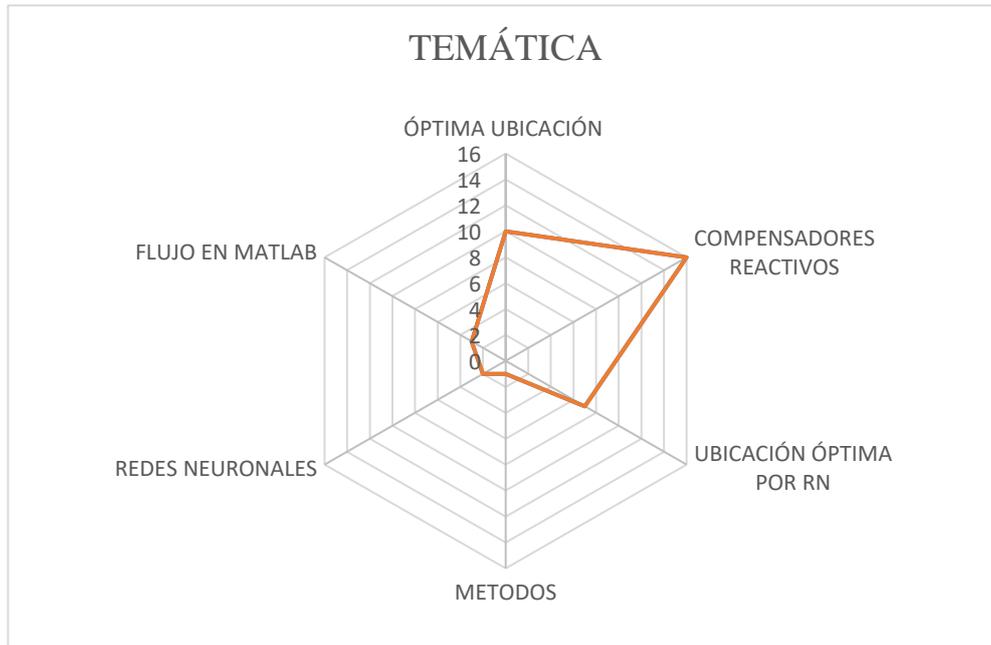


Figura 25. Resumen e indicador de la temática - Estado del arte

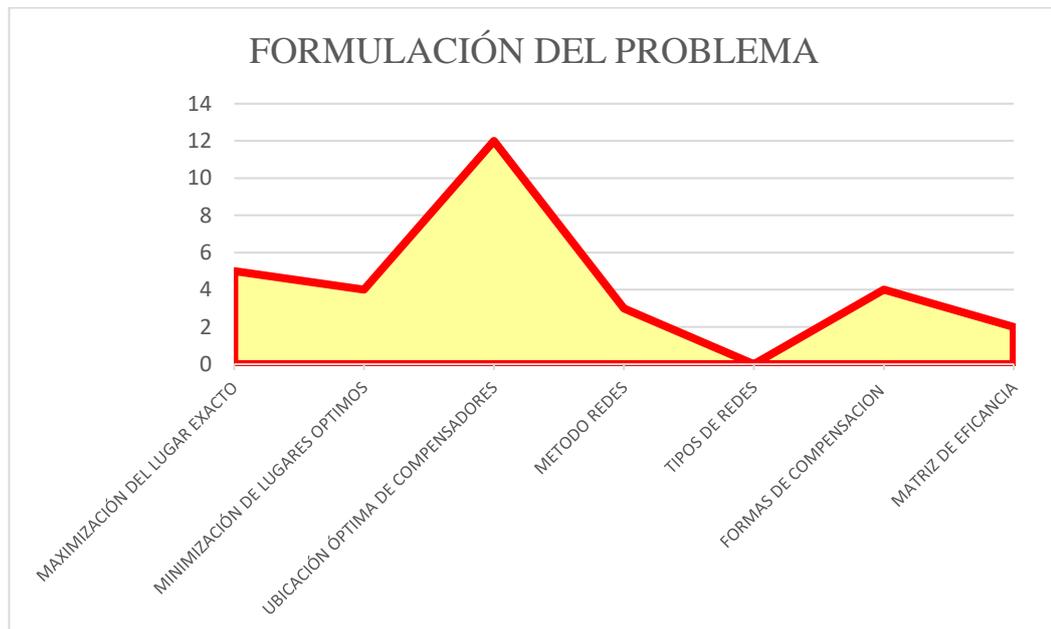


Figura 26. Indicador de la formulación del problema - Estado del arte

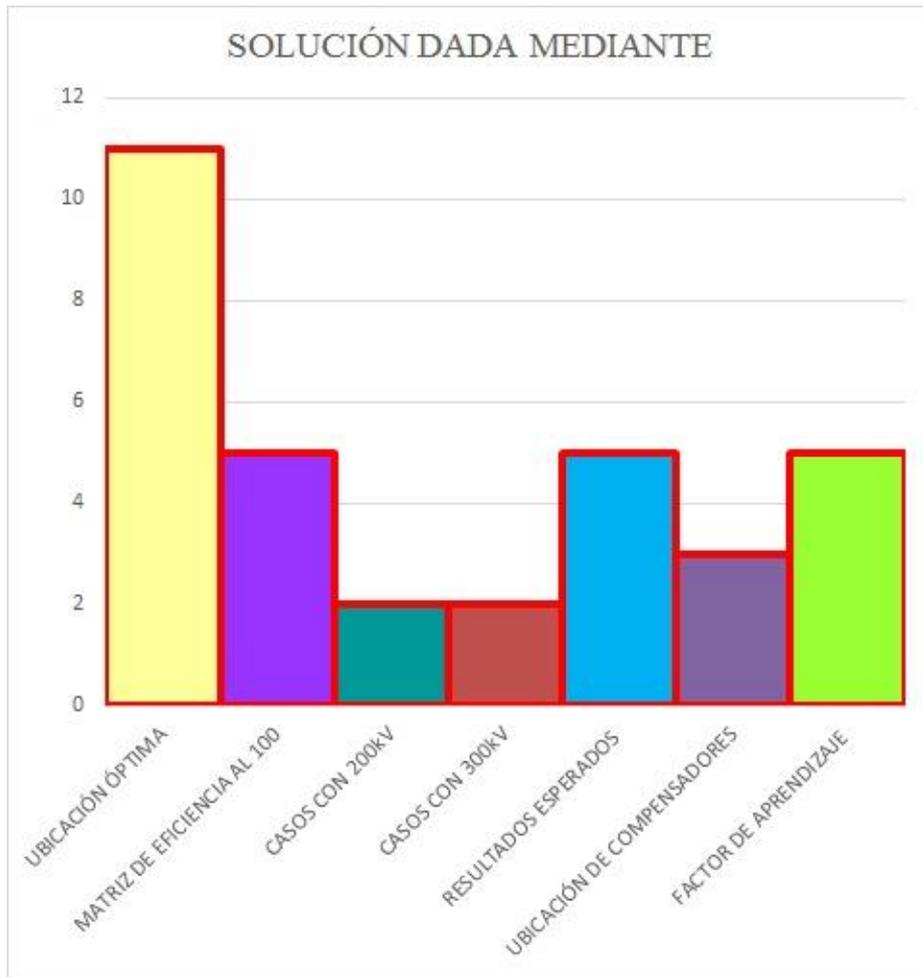


Figura 13. Indicador de solución - Estado del arte